

## AIによる生コンクリートの荷卸し時スランプ予測

太平洋セメント株式会社 正会員 ○工藤 正智  
 太平洋セメント株式会社 正会員 小池 耕太郎  
 太平洋セメント株式会社 正会員 早野 博幸

## 1. はじめに

生コン工場の製造過程においては、ミキサ内の練混ぜ時にコンクリートの動きを目視で確認し、スランプを管理して生コンクリートを出荷している。そこで、練混ぜ時のスランプを瞬時にかつ正確に予測できる技術の開発が望まれる。既往の検討では、練混ぜ画像を用い、AIとして畳み込みニューラルネットワークを適用することで出荷時のスランプを予測できることが報告されている。しかし、実際にはコンクリートを製造してから現場の荷卸しまでアジテータ車で運搬するため、生コン工場ではスランプの変動である『スランプロス』を考慮してコンクリートを出荷しており、荷卸し時スランプも併せて出荷時に予測できるとさらに有用性が高くなる。

そこで本検討では、AIとして機械学習を用いて、生コン工場から出荷する時点で取得可能な各種データを学習させてAIモデルを作成し、荷卸し時スランプおよびスランプフローの予測を行い、予測精度を検証した。

## 2. 実験概要

学習ライブラリとしては、Google社で開発されオープンソースとして公開しているTensorFlowを使用し、ディープニューラルネットワーク(DNN: Deep Neural Network)によりAIモデルを作成した。学習データとしては、出荷時スランプを含む12項目を入力項目とし、荷卸し時スランプまたはスランプフローの1項目を出力させるAIモデルとした。また、使用データ数は、荷卸し時スランプの全データ数779件のうち学習データ数598件、検証データ数181件とし、荷卸し時スランプフローの全データ数1163件のうち学習データ数891件、検証データ数272件とした。荷卸し時スランプとスランプフローはそれぞれ別のAIモデルとして作成し、いずれも学習回数を20万回として、層化k分割交差検証を行い4分割して予測精度を検証した。使用データを表1に示す。データ項目としては、荷卸し時スラン

プに影響を及ぼす材料(配合)・製造・運搬に関する項目を選定した。また、使用データとしては、年間の変動を考慮し、生コン工場における約1年間分のデータを用いた。なお、外気温はコンクリート製造開始時刻における気象庁データベースの気温とした。また、出荷時スランプおよびスランプフローは実測値を用いている。

さらに、学習データとして使用したデータ項目とスランプロスとの関係を確認し、荷卸し時スランプに及ぼす要因を検討した。また、スランプごとのデータ数に偏りがあることから、スランプによるデータ数と予測精度との関係も併せて検証した。

## 3. 結果および考察

AIによる荷卸し時スランプおよびスランプフローの予測精度を表2に示す。予測値と実測値の差が許容差範囲内に収まるデータ数の割合を正解率とした。表より、スランプでは許容差 $\pm 2.0$  cm以内の正解率が94.2%、 $\pm 2.5$  cm以内の正解率が97.5%となり、スランプフロー

表1 使用データ

入力項目			
No.	データ項目	範囲	種別
1	W/C	21~74(%)	材料 (配合)
2	セメント種類	5種類	
3	混和剤種類	10種類	
4	混和剤量	2.0~10.1(kg)	
5	単位水量	160~305 <sup>※1</sup> (kg)	
6	出荷時スランプ or スランプフロー	10~25.5(cm) 22.5~74.5(cm)	製造
7	電力負荷値	0.4~5.8(kW)	
8	外気温	-1.4~32.9(°C)	
9	製造日付	mm/dd	
10	製造時刻	hh:mm	運搬
11	積載量	1~5 <sup>※2</sup> (m <sup>3</sup> )	
12	運搬時間	8~120(分)	
出力項目			
No.	データ項目	範囲	種別
1	荷卸し時スランプ or スランプフロー	7.5~25.0(cm) 24.0~73.0(cm)	—

※1 モルタルを含む ※2 軽量コンクリートを含む

キーワード AI, コンクリート, スランプ, 機械学習, 深層学習

連絡先 〒285-8655 千葉県佐倉市大作2-4-2 太平洋セメント(株)中央研究所 TEL043-498-3902

では±5.0 cm 以内の正解率が 95.0%, ±7.5 cm 以内の正解率が 99.1% となったことから、スランプ、スランプフローともに AI により高精度で予測できることがわかる。

続いて、荷卸し時スランプ、外気温および運搬時間とスランプロスの関係を図 1 から図 3 に示す。荷卸し時スランプが大きくなるとスランプロスが低下する傾向を示した。一方、外気温、運搬時間とスランプロスとの関係では、運搬時間についてはスランプロスとの間に僅かに負の相関を示したが、いずれも明確な関係は得られなかった。これは、同一配合の場合には、一般的に外気温が高くなる、または運搬時間が長くなるとスランプロスが大きくなると予想されるが、本検討中には様々な配合が含まれていること、生コン工場では外気温や運搬時間を考慮して配合条件や混和剤種類・添加量を決定することなどから、これらとスランプロスとの間に明確な関係が得られなかったと考えられる。すなわち、外気温や運搬時間といった単独の要因ではスランプロスを評価できず、多くの複合的な要因を考慮できる AI が有効であることがわかる。

スランプごとの学習データ数と許容差±1.0, ±1.5 cm 以内における平均正解率の関係を図 4 に示す。図中に示す通り、12.0, 12.5, 13.5 cm と取得スランプ下限値に近い場合、学習データ数が 10 件以下であるため正解率が低くなった。また、許容差によらず全体的な傾向として、学習データ数が多いほど正解率が高くなり、許容差±1.5 cm においては、学習データ数 30 件以上では概ね正解率が 80% を超えることがわかる。以上より、本検討においてデータ数の少ないスランプについても、データ数を増やすことで正解率が向上すると考えられる。

今後、荷卸し時スランプを予測する AI モデルの入力データとして、練混ぜ画像による出荷時スランプ予測値を用いることで、練混ぜ中に荷卸し時スランプを予測できる手法を検討予定である。

#### 4. まとめ

生コン工場の材料(配合)・製造・運搬データを用い、AI による予測を行った結果、荷卸し時スランプおよびスランプフローともに高精度で予測可能であった。また、単独のデータではスランプロスを評価できないこと、さらに学習データ数を増加することで予測精度の向上が期待できることから、荷卸し時スランプ予測に AI を適用することが有効であることがわかった。

表 2 AI による予測精度

許容差(cm)	±1.0	±1.5	±2.0	±2.5
スランプ	71.1%	86.2%	94.2%	97.5%
許容差(cm)	±2.5	±5.0	±7.5	±10.0
スランプフロー	70.5%	95.0%	99.1%	99.9%

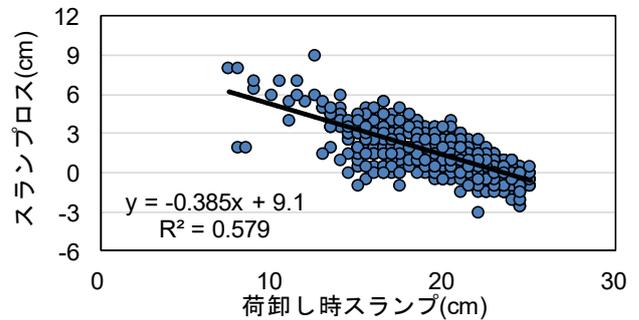


図 1 荷卸し時スランプとスランプロスとの関係

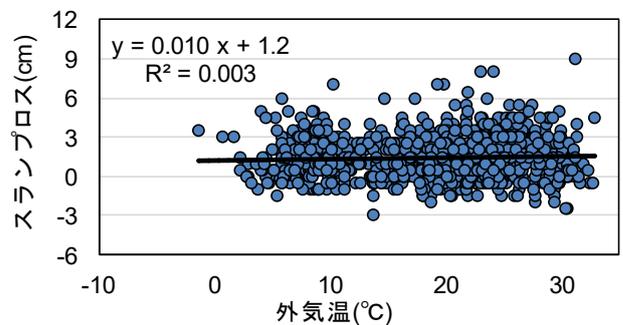


図 2 外気温とスランプロスとの関係

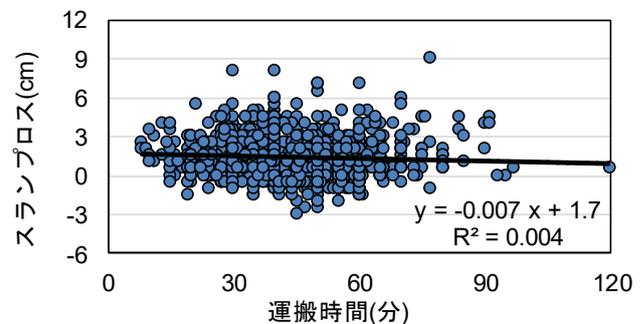


図 3 運搬時間とスランプロスとの関係

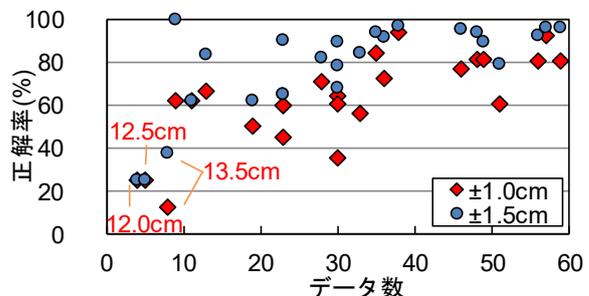


図 4 データ数と正解率との関係

#### 参考文献

- 1) 早野博幸ほか: AI 技術を用いたフレッシュコンクリートのスランプ予測, 土木学会年次学術講演会講演概要集, Vol.74, No.5, pp.505-506, 2019